(12) DEMANDE INTERNATIONALE PUBLIÉE EN VERTU DU TRAITÉ DE COOPÉRATION EN MATIÈRE DE BREVETS (PCT)

(19) Organisation Mondiale de la Propriété Intellectuelle
Bureau international

(43) Date de la publication internationale
10 novembre 2005 (10.11.2005)

PCT

(10) Numéro de publication internationale
WO 2005/106852 A1

(51) Classification internationale des brevets[7] : G10L 21/00, 13/02

(21) Numéro de la demande internationale : PCT/FR2005/000564

(22) Date de dépôt international : 9 mars 2005 (09.03.2005)

(25) Langue de dépôt : français

(26) Langue de publication : français

(30) Données relatives à la priorité :
0403403 31 mars 2004 (31.03.2004) FR

(71) Déposant *(pour tous les États désignés sauf US)* : **FRANCE TELECOM** [FR/FR]; 6, place d'Alleray, F-75015 Paris (FR).

(72) Inventeurs; et

(75) Inventeurs/Déposants *(pour US seulement)* : **EN-NAJJARY, Touafik** [FR/FR]; FJT, 3, rue Soutrane Garbejaïre, 06560 Valbonne (FR). **ROSEC, Olivier** [FR/FR]; 29, rue André Gide, F-22300 Lannion (FR).

(74) Mandataires : **HABASQUE, Etienne** etc.; Cabinet Lavoix, 2, place d'Estienne d'Orves, F-75441 Paris Cedex 09 (FR).

[Suite sur la page suivante]

(54) Title: IMPROVED VOICE SIGNAL CONVERSION METHOD AND SYSTEM

(54) Titre : PROCEDE ET SYSTEME AMELIORES DE CONVERSION D'UN SIGNAL VOCAL

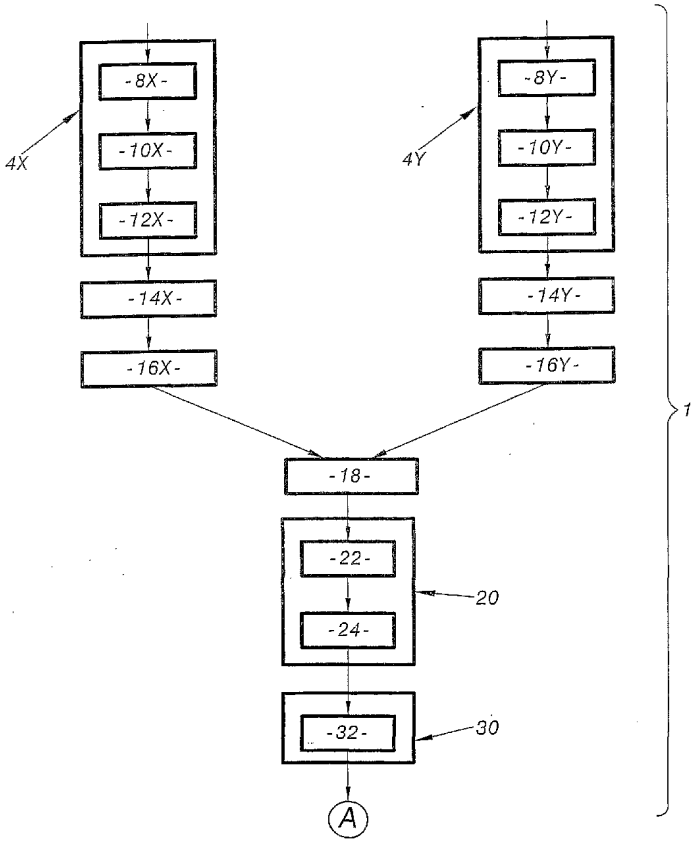

transformation conjointe de caractéristiques relatives

(57) Abstract: The invention relates to a method of converting a voice signal spoken by a source speaker into a converted voice signal having acoustic characteristics that resemble those of a target speaker. The inventive method comprises the following steps consisting in: determining (1) at least one function for the transformation of the acoustic characteristics of the source speaker into acoustic characteristics similar to those of the target speaker; and transforming the acoustic characteristics of the voice signal to be converted using said at least one transformation function. The invention is characterised in that: (i) the aforementioned transformation function-determining step (1) consists in determining (1) a function for the joint transformation of characteristics relating to the spectral envelope and characteristics relating to the fundamental frequency of the source speaker; and (ii) said transformation comprises the application of the joint transformation function.

(57) Abrégé : Ce procédé de conversion d'un signal vocal prononcé par un locuteur source en un signal vocal converti dont les caractéristiques acoustiques ressemblent à celles d'un locuteur cible, comprend : - la détermination (1) d'au moins une fonction de transformation de caractéristiques acoustiques du locuteur source en caractéristiques acoustiques proches de celles du locuteur cible ; et - la transformation de caractéristiques acoustiques du signal vocal à convertir, par ladite au moins une fonction de transformation. Il est caractérisé en ce que ladite détermination (1) comprend la détermination (1) d'une fonction de

[Suite sur la page suivante]

WO 2005/106852 A1

(81) États désignés *(sauf indication contraire, pour tout titre de protection nationale disponible)* **:** AE, AG, AL, AM, AT, AU, AZ, BA, BB, BG, BR, BW, BY, BZ, CA, CH, CN, CO, CR, CU, CZ, DE, DK, DM, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, HR, HU, ID, IL, IN, IS, JP, KE, KG, KP, KR, KZ, LC, LK, LR, LS, LT, LU, LV, MA, MD, MG, MK, MN, MW, MX, MZ, NA, NI, NO, NZ, OM, PG, PH, PL, PT, RO, RU, SC, SD, SE, SG, SK, SL, SM, SY, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, YU, ZA, ZM, ZW.

(84) États désignés *(sauf indication contraire, pour tout titre de protection régionale disponible)* **:** ARIPO (BW, GH, GM, KE, LS, MW, MZ, NA, SD, SL, SZ, TZ, UG, ZM, ZW), eurasien (AM, AZ, BY, KG, KZ, MD, RU, TJ, TM), européen (AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HU, IE, IS, IT, LT, LU, MC, NL, PL, PT, RO, SE, SI, SK, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, ML, MR, NE, SN, TD, TG).

Publiée :

— *avec rapport de recherche internationale*

En ce qui concerne les codes à deux lettres et autres abréviations, se référer aux "Notes explicatives relatives aux codes et abréviations" figurant au début de chaque numéro ordinaire de la Gazette du PCT.

à l'enveloppe spectrale et de caractéristiques relatives à la fréquence fondamentale du locuteur source et en ce que ladite transformation comprend l'application de ladite fonction de transformation conjointe.

Procédé et système améliorés de conversion d'un signal vocal

La présente invention concerne un procédé de conversion d'un signal vocal prononcé par un locuteur source en un signal vocal converti dont les caractéristiques acoustiques ressemblent à celles d'un locuteur cible et un système de conversion correspondant.

Dans le cadre d'applications de conversion de voix, telles que les services vocaux, les applications de dialogue oral homme-machine ou encore la synthèse vocale de textes, le rendu auditif est primordial et, pour obtenir une qualité acceptable, il convient de bien maîtriser les paramètres acoustiques des signaux vocaux.

De manière classique, les principaux paramètres acoustiques ou prosodiques modifiés lors de procédés de conversion de voix sont les paramètres relatifs à l'enveloppe spectrale, et pour les sons voisés faisant intervenir la vibration des cordes vocales, les paramètres relatifs à une structure périodique, soit la période fondamentale dont l'inverse est appelé fréquence fondamentale ou « pitch ».

Les procédés de conversion de voix classiques sont essentiellement fondés sur des modifications des caractéristiques d'enveloppe spectrale et des modifications globales des caractéristiques de fréquence fondamentale.

Une étude plus récente, publiée à l'occasion de la conférence EUROSPEECH 2003 sous le titre *« A new method for pitch prediction from spectral envelope and its application in voice conversion »* par Taoufik En-Najjary, Olivier Rosec and Thierry Chonavel, prévoit la possibilité d'affiner la modification des caractéristiques de fréquence fondamentale en définissant une fonction de prédiction de ces caractéristiques, en fonction de caractéristiques d'enveloppe spectrale.

Ainsi, ce procédé permet de modifier les caractéristiques d'enveloppe spectrale, et en fonction de celles-ci, de modifier les caractéristiques de fréquence fondamentale.

Ce procédé présente toutefois l'inconvénient important de rendre la modification des caractéristiques de fréquence fondamentale dépendantes de la modification des caractéristiques d'enveloppe spectrale. Ainsi une erreur de transformation de l'enveloppe spectrale se répercute automatiquement sur la prédiction de fréquence fondamentale.

De plus, la mise en œuvre d'un tel procédé requiert deux étapes importantes de calcul, soit la modification des caractéristiques d'enveloppe spectrale et la prédiction de la fréquence fondamentale, aboutissant ainsi à doubler la complexité du système dans son ensemble.

Le but de la présente invention est de résoudre ces problèmes en définissant un procédé de conversion de voix simple et plus efficace.

A cet effet, la présente invention a pour objet un procédé de conversion d'un signal vocal prononcé par un locuteur source en un signal vocal converti dont les caractéristiques acoustiques ressemblent à celles d'un locuteur cible, comprenant :

- la détermination d'au moins une fonction de transformation de caractéristiques acoustiques du locuteur source en caractéristiques acoustiques proches de celles du locuteur cible, à partir d'échantillons vocaux des locuteurs source et cible ; et
- la transformation de caractéristiques acoustiques du signal vocal à convertir du locuteur source, par l'application de ladite au moins une fonction de transformation,

caractérisé en ce que ladite détermination comprend la détermination d'une fonction de transformation conjointe de caractéristiques relatives à l'enveloppe spectrale et de caractéristiques relatives à la fréquence fondamentale du locuteur source et en ce que ladite transformation comprend l'application de ladite fonction de transformation conjointe.

Ainsi, le procédé de l'invention permet la modification simultanée au cours d'une seule opération des caractéristiques d'enveloppe spectrale et de fréquence fondamentale sans créer de dépendance entre celles-ci.

Suivant d'autres caractéristiques de l'invention :

- ladite détermination d'une fonction de transformation conjointe comprend :
  - une étape d'analyse des échantillons vocaux des locuteurs source et cible regroupés en trames pour obtenir, pour chaque trame d'échantillons d'un locuteur, des informations relatives à l'enveloppe spectrale et à la fréquence fondamentale ;

- une étape de concaténation des informations relatives à l'enveloppe spectrale et à la fréquence fondamentale pour chacun des locuteurs source et cible ;

- une étape de détermination d'un modèle représentant des caractéristiques acoustiques communes des échantillons vocaux du locuteur source et du locuteur cible ; et

- une étape de détermination, à partir de ce modèle et des échantillons vocaux, de ladite fonction de transformation conjointe ;

- lesdites étapes d'analyse des échantillons vocaux des locuteurs source et cible sont adaptées pour délivrer lesdites informations relatives à l'enveloppe spectrale sous la forme de coefficients cepstraux ;

- lesdites étapes d'analyse comprennent chacune la modélisation des échantillons vocaux selon une somme d'un signal harmonique et d'un signal de bruit qui comprend :

- une sous-étape d'estimation de la fréquence fondamentale des échantillons vocaux ;

- une sous-étape d'analyse synchronisée de chaque trame d'échantillons sur sa fréquence fondamentale ; et

- une sous-étape d'estimation de paramètres d'enveloppe spectrale de chaque trame d'échantillons.

- ladite étape de détermination d'un modèle correspond à la détermination d'un modèle de mélange de densités de probabilités gaussiennes;

- ladite étape de détermination d'un modèle comprend :

- une sous-étape de détermination d'un modèle correspondant à un mélange de densité de probabilités gaussiennes, et

- une sous-étape d'estimation des paramètres du mélange de densités de probabilités gaussiennes à partir de l'estimation du maximum de vraisemblance entre les caractéristiques acoustiques des échantillons des locuteurs source et cible et le modèle ;

- ladite détermination d'au moins une fonction de transformation, comporte en outre une étape de normalisation de la fréquence fondamentale des trames d'échantillons des locuteurs source et cible respectivement par rapport aux moyennes des fréquences fondamentales des échantillons analysés des locuteurs source et cible ;

- le procédé comporte une étape d'alignement temporel des caractéristiques acoustiques du locuteur source avec les caractéristiques acoustiques du locuteur cible, cette étape étant réalisée avant ladite étape de détermination d'un modèle ;

- le procédé comporte une étape de séparation dans les échantillons vocaux du locuteur source et du locuteur cible, des trames à caractère voisé et des trames à caractère non voisé, ladite détermination d'une fonction de transformation conjointe des caractéristiques relatives à l'enveloppe spectrale et à la fréquence fondamentale étant réalisée uniquement à partir desdites trames voisées et le procédé comportant une détermination d'une fonction de transformation des seules caractéristiques d'enveloppe spectrale uniquement à partir desdites trames non voisées ;

- ladite détermination d'au moins une fonction de transformation comprend uniquement ladite étape de détermination d'une fonction de transformation conjointe ;

- ladite détermination d'une fonction de transformation conjointe est réalisée à partir d'un estimateur de la réalisation des caractéristiques acoustiques du locuteur cible sachant les caractéristiques acoustiques du locuteur source ;

- ledit estimateur est formé de l'espérance conditionnelle de la réalisation des caractéristiques acoustiques du locuteur cible sachant la réalisation des caractéristiques acoustiques du locuteur source ;

- ladite transformation de caractéristiques acoustiques du signal vocal à convertir, comporte :

- une étape d'analyse de ce signal vocal, regroupé en trames pour obtenir, pour chaque trame d'échantillons, des informations relatives à l'enveloppe spectrale et à la fréquence fondamentale ;

- une étape de formatage des informations acoustiques relatives à l'enveloppe spectrale et à la fréquence fondamentale du signal vocal à convertir ; et

- une étape de transformation des informations acoustiques formatées du signal vocal à convertir à l'aide de ladite fonction de transformation conjointe ;

- le procédé comporte une étape de séparation, dans ledit signal vocal à convertir, des trames voisées et des trames non voisées, ladite étape de transformation comprenant :

- une sous-étape d'application de ladite fonction de transformation conjointe aux seules trames voisées dudit signal à convertir ; et

- une sous-étape d'application de ladite fonction de transformation des seules caractéristiques d'enveloppe spectrale auxdites trames non voisées dudit signal à convertir ;

- ladite étape de transformation comprend l'application de ladite fonction de transformation conjointe aux caractéristiques acoustiques de toutes les trames dudit signal vocal à convertir ;

- le procédé comporte en outre une étape de synthèse permettant de former un signal vocal converti à partir des dites informations acoustiques transformées.

L'invention a également pour objet un système de conversion d'un signal vocal prononcé par un locuteur source en un signal vocal converti dont les caractéristiques acoustiques ressemblent à celles d'un locuteur cible, comprenant :

- des moyens de détermination d'au moins une fonction de transformation des caractéristiques acoustiques du locuteur source en caractéristiques acoustiques proches du locuteur cible, à partir d'échantillons vocaux prononcés par les locuteurs source et cible : et

- des moyens de transformation des caractéristiques acoustiques du signal vocal à convertir du locuteur source par l'application de ladite au moins une fonction de transformation,

caractérisé en ce que lesdits moyens de détermination d'au moins une fonction de transformation, comprennent une unité de détermination d'une fonction de transformation conjointe de caractéristiques relatives à l'enveloppe spectrale et de caractéristiques relatives à la fréquence fondamentale du locuteur source et en ce que lesdits moyens de transformation comportent des moyens d'application de ladite fonction de transformation conjointe.

Selon d'autres caractéristiques de ce système :

- il comporte en outre :

- des moyens d'analyse du signal vocal à convertir, adaptés pour délivrer en sortie des informations relatives à l'enveloppe spectrale et à la fréquence fondamentale du signal vocal à convertir ; et

- des moyens de synthèse permettant de former un signal vocal converti à partir au moins desdites informations d'enveloppe spectrale et de fréquence fondamentale transformées simultanément ;

- lesdits moyens de détermination d'au moins une fonction de transformation de caractéristiques acoustiques comportent en outre une unité de détermination d'une fonction de transformation de l'enveloppe spectrale des trames non voisées, ladite unité de détermination de la fonction de transformation conjointe étant adaptée pour la détermination de la fonction de transformation conjointe uniquement pour les trames voisées.

L'invention sera mieux comprise à la lecture de la description qui va suivre, donnée uniquement à titre d'exemple et faite en se référant aux dessins annexés, sur lesquels :

- les Figs. 1A et 1B forment un organigramme général d'un premier mode de réalisation du procédé de l'invention ;

- les Figs. 2A et 2B forment un organigramme général d'un second mode de réalisation du procédé de l'invention ;

- la Fig. 3 est un graphique représentant un relevé expérimental des performances du procédé de l'invention ; et

- la Fig. 4 est un schéma synoptique d'un système mettant en œuvre un procédé selon l'invention.

La conversion de voix consiste à modifier le signal vocal d'un locuteur de référence appelé locuteur source, de telle sorte que le signal produit semble avoir été prononcé par un autre locuteur, nommé locuteur cible.

Un tel procédé comporte tout d'abord la détermination de fonctions de transformation de caractéristiques acoustiques ou prosodiques des signaux vocaux du locuteur source en caractéristiques acoustiques proches de celles des signaux vocaux du locuteur cible, à partir d'échantillons vocaux prononcés par le locuteur source et le locuteur cible.

Plus particulièrement, la détermination 1 de fonctions de transformation est réalisée sur des bases de données d'échantillons vocaux

correspondant à la réalisation acoustique de mêmes séquences phonétiques prononcées respectivement par les locuteurs source et cible.

Cette détermination est désignée sur la figure 1A par la référence numérique générale 1 et est également couramment appelée « apprentissage ».

Le procédé comporte ensuite une transformation des caractéristiques acoustiques d'un signal vocal à convertir prononcé par le locuteur source à l'aide de la ou des fonctions déterminées précédemment. Cette transformation est désignée par la référence numérique générale 2 sur la figure 1B.

Le procédé débute par des étapes 4X et 4Y d'analyse des échantillons vocaux prononcés respectivement par les locuteurs source et cible. Ces étapes permettent de regrouper les échantillons par trames, afin d'obtenir pour chaque trame d'échantillons, des informations relatives à l'enveloppe spectrale et des informations relatives à la fréquence fondamentale.

Dans le mode de réalisation décrit, les étapes 4X et 4Y d'analyse sont fondées sur l'utilisation d'un modèle de signal sonore sous la forme d'une somme d'un signal harmonique avec un signal de bruit selon un modèle communément appelé "HNM" (en anglais : Harmonic plus Noise Model).

Le modèle HNM comprend la modélisation de chaque trame de signal vocal en une partie harmonique représentant la composante périodique du signal, constituée d'une somme de L sinusoïdes harmoniques d'amplitude A_l et de phase ϕ_l, et d'une partie bruitée représentant le bruit de friction et la variation de l'excitation glottale.

On peut ainsi écrire :

$s(n)=h(n)+b(n)$

avec $h(n)= \sum_{l=1}^{L} A_l(n)\cos(\phi_l(n))$

Le terme h(n) représente donc l'approximation harmonique du signal s(n).

En outre, le mode de réalisation décrit est fondé sur une représentation de l'enveloppe spectrale par le cepstre discret.

Les étapes 4X et 4Y comportent des sous-étapes 8X et 8Y d'estimation pour chaque trame, de la fréquence fondamentale, par exemple au moyen d'une méthode d'autocorrélation.

Les sous-étapes 8X et 8Y sont chacune suivies d'une sous-étape 10X et 10Y d'analyse synchronisée de chaque trame sur sa fréquence fondamentale, qui permet d'estimer les paramètres de la partie harmonique ainsi que les paramètres du bruit du signal et notamment la fréquence maximale de voisement. En variante, cette fréquence peut être fixée arbitrairement ou être estimée par d'autres moyens connus.

Dans le mode de réalisation décrit, cette analyse synchronisée correspond à la détermination des paramètres des harmoniques par minimisation d'un critère de moindres carrés pondérés entre le signal complet et sa décomposition harmonique correspondant dans le mode de réalisation décrit, au signal de bruit estimé. Le critère noté E est égal à :

$$E = \sum_{n=-T_i}^{T_i} w^2(n)(s(n)-h(n))^2$$

Dans cette équation, w (n) est la fenêtre d'analyse et T_i est la période fondamentale de la trame courante.

Ainsi, la fenêtre d'analyse est centrée autour de la marque de la période fondamentale et a pour durée deux fois cette période.

En variante, ces analyses sont faites de manière asynchrone avec un pas fixe d'analyse et une fenêtre de taille fixe.

Les étapes 4X et 4Y d'analyse comportent enfin des sous-étapes 12X et 12Y d'estimation des paramètres de l'enveloppe spectrale des signaux en utilisant par exemple une méthode de cepstre discret régularisé et une transformation en échelle de Bark pour reproduire le plus fidèlement possible les propriétés de l'oreille humaine.

Ainsi, les étapes 4X et 4Y d'analyse délivrent respectivement pour les échantillons vocaux prononcés par les locuteurs source et cible, pour chaque trame de rang n d'échantillons des signaux de parole, un scalaire noté F_n représentant la fréquence fondamentale et un vecteur noté c_n comprenant des informations d'enveloppe spectrale sous la forme d'une séquence de coefficients cepstraux.

Le mode de calcul des coefficients cepstraux correspond à un mode opératoire connu de l'état de la technique et, pour cette raison, ne sera pas décrit plus en détail.

Avantageusement, les étapes 4X et 4Y d'analyse sont suivies chacune par une étape 14 X et 14Y de normalisation de la valeur de la fréquence fondamentale de chaque trame par rapport respectivement aux fréquences fondamentales des locuteurs source et cible afin de remplacer, pour chaque trame d'échantillons vocaux, la valeur de la fréquence fondamentale par une valeur de fréquence fondamentale normalisée selon la formule suivante :

$$g = F_{log} = \log\left(\frac{Fo}{F_o^{moy}}\right)$$

Dans cette formule, F_o^{moy} correspond aux moyennes des valeurs des fréquences fondamentales sur chaque base de données analysée, soit sur la base de données d'échantillons vocaux du locuteur source et du locuteur cible.

Cette normalisation permet de modifier, pour chaque locuteur, l'échelle de variations des scalaires de fréquence fondamentale afin de la rendre cohérente avec l'échelle des variations des coefficients cepstraux. Pour chaque trame n, on note $g_x(n)$ la fréquence fondamentale normalisée pour le locuteur source et $g_y(n)$ celle du locuteur cible.

Le procédé de l'invention comporte ensuite des étapes 16X et 16Y de concaténation pour chaque locuteur source et cible, des informations d'enveloppe spectrale et de fréquence fondamentale sous la forme d'un unique vecteur.

Ainsi, l'étape 16X permet de définir pour chaque trame n un vecteur noté x_n regroupant les coefficients cepstraux $c_x(n)$ et la fréquence fondamentale normalisée $g_x(n)$ selon l'équation suivante :

$$x_n = \left[c_X^T(n), g_X(n)\right]^T$$

Dans cette équation, T désigne l'opérateur de transposition.

De manière similaire, l'étape 16Y permet de former pour chaque trame n, un vecteur y_n reprenant les coefficients cepstraux $c_y(n)$ et la fréquence fondamentale normalisée $g_y(n)$ selon l'équation suivante :

$$y_n = \left[c_Y^T(n), g_Y(n)\right]^T$$

Les étapes 16 X et 16Y sont suivies d'une étape 18 d'alignement entre le vecteur source x_n et le vecteur cible y_n, de manière à former un appariement entre ces vecteurs obtenu par un algorithme classique d'alignement temporel dynamique dit « DTW » (en anglais : Dynamic Time Warping).

En variante, l'étape 18 d'alignement est mise en œuvre uniquement à partir des coefficients cepstraux sans utiliser les informations de fréquence fondamentale.

L'étape 18 d'alignement délivre donc un vecteur couple formé de couples de coefficients cepstraux et d'informations de fréquence fondamentale des locuteurs source et cible, alignés temporellement.

L'étape 18 d'alignement est suivie d'une étape 20 de détermination d'un modèle représentant les caractéristiques acoustiques communes du locuteur source et du locuteur cible à partir des informations d'enveloppe spectrale et de fréquence fondamentale de tous les échantillons analysés.

Dans le mode de réalisation décrit, il s'agit d'un modèle probabiliste des caractéristiques acoustiques du locuteur cible et du locuteur source, selon un modèle de mélange de densités de probabilités gaussiennes, couramment noté "GMM", dont les paramètres sont estimés à partir des vecteurs source et cible contenant, pour chaque locuteur, la fréquence fondamentale normalisée et le cepstre discret.

De manière classique, la densité de probabilité d'une variable aléatoire notée de manière générale p(z), suivant un modèle de mélange de densités gaussiennes GMM s'écrit mathématiquement de la manière suivante :

$$p(z)=\sum_{i=1}^{Q}\alpha_i x(z,\mu;\Sigma_i)$$

avec $\sum_{i=1}^{Q}\alpha_i = 1$, $o \leq \alpha_i \leq 1$

Dans cette formule, Q désigne le nombre de composantes du modèle, $N(z ; \mu_i, \Sigma_i)$ est la densité de probabilité de la loi normale de moyenne μ_i et de matrice de covariance Σ_i et les coefficients α_i sont les coefficients du mélange.

Ainsi, le coefficient α_i correspond à la probabilité a priori que la variable aléatoire z soit générée par la $i^{ème}$ composante gaussienne du mélange.

De manière plus particulière, l'étape 20 de détermination du modèle comporte une sous-étape 22 de modélisation de la densité jointe p(z) des vecteurs source noté x et cible noté y, de sorte que :

$$Z_n=\left[{}^{T}x_n\ ,\ {}^{T}y_n\right]^{T}$$

L'étape 20 comporte ensuite une sous-étape 24 d'estimation de paramètres GMM (α, μ, Σ) de la densité p(z). Cette estimation peut être réalisée, par exemple, à l'aide d'un algorithme classique de type dit "EM" (Expectation – Maximisation), correspondant à une méthode itérative conduisant à l'obtention d'un estimateur de maximum de vraisemblance entre les données des échantillons de parole et le modèle de mélange de gaussiennes.

La détermination des paramètres initiaux du modèle GMM est obtenue à l'aide d'une technique classique de quantification vectorielle.

L'étape 20 de détermination de modèle délivre ainsi les paramètres d'un mélange de densités gaussiennes, représentatif des caractéristiques acoustiques communes et en particulier d'enveloppe spectrale et de fréquence fondamentale, des échantillons vocaux du locuteur source et du locuteur cible.

Le procédé comporte ensuite une étape 30 de détermination, à partir du modèle et des échantillons vocaux, d'une fonction conjointe de transformation de la fréquence fondamentale et de l'enveloppe spectrale fournie par le cepstre, du signal du locuteur source vers le locuteur cible.

Cette fonction de transformation est déterminée à partir d'un estimateur de la réalisation des caractéristiques acoustiques du locuteur cible étant donné les caractéristiques acoustiques du locuteur source, formé dans le mode de réalisation décrit, par l'espérance conditionnelle.

Pour cela, l'étape 30 comporte une sous-étape 32 de détermination de l'espérance conditionnelle des caractéristiques acoustiques du locuteur cible sachant les informations caractéristiques acoustiques du locuteur source. L'espérance conditionnelle est notée F(x) et est déterminée à partir des formules suivantes :

$$F(x)=E[y\mid x]=\sum_{i=1}^{Q} h_i(x)\left[\mu_i^{y}+\Sigma_i^{yx}\left(\Sigma_i^{xx}\right)^{-1}\left(x-\mu_i^{x}\right)\right]$$

avec $h_i(x)=\frac{\alpha_i N(x,\mu_i^x,\Sigma_i^{xx})}{\sum_{j=1}^{Q}\alpha_j N(x,\mu_j^x,\Sigma_j^{xx})}$

avec $\Sigma_i=\begin{bmatrix}\Sigma_i^{xx} & \Sigma_i^{xy}\\ \Sigma_i^{yx} & \Sigma_i^{yy}\end{bmatrix}$ et $\mu_i=\begin{bmatrix}\mu_i^x\\ \mu_i^y\end{bmatrix}$

Dans ces équations, $h_i(x)$ correspond à la probabilité a posteriori que le vecteur source x soit généré par la $i^{ème}$ composante du modèle de mélange de densités gaussiennes du modèle.

La détermination de l'espérance conditionnelle permet ainsi d'obtenir la fonction de transformation conjointe des caractéristiques d'enveloppe spectrale et de fréquence fondamentale entre le locuteur source et le locuteur cible.

Il apparaît donc que le procédé d'analyse de l'invention permet, à partir du modèle et des échantillons vocaux, d'obtenir une fonction de transformation conjointe des caractéristiques acoustiques de fréquence fondamentale et d'enveloppe spectrale.

En référence à la figure 1B, le procédé de conversion comporte ensuite la transformation 2 d'un signal vocal à convertir prononcé par le locuteur source, lequel signal à convertir peut être différent des signaux vocaux utilisés précédemment.

Cette transformation 2 débute par une étape d'analyse 36 réalisée, dans le mode de réalisation décrit, à l'aide d'une décomposition selon le modèle HNM similaire à celles réalisées dans les étapes 4X et 4Y décrites précédemment. Cette étape 36 permet de délivrer des informations d'enveloppe spectrale sous la forme de coefficients cepstraux, des informations de fréquence fondamentale ainsi que des informations de phase et de fréquence maximale de voisement.

L'étape 36 est suivie d'une étape 38 de formatage des caractéristiques acoustiques du signal à convertir par normalisation de la fréquence fondamentale et concaténation avec les coefficients cepstraux afin de former un unique vecteur.

Cet unique vecteur est utilisé lors d'une étape 40 de transformation des caractéristiques acoustiques du signal vocal à convertir par l'application de la fonction de transformation déterminée à l'étape 30, aux coefficients cepstraux du

signal à convertir définis lors de l'étape 36, ainsi qu'aux informations de fréquence fondamentale.

A l'issue de l'étape 40, chaque trame d'échantillons du signal à convertir du locuteur source est ainsi associée à des informations d'enveloppe spectrale et de fréquence fondamentale transformées simultanément, dont les caractéristiques sont similaires à celles des échantillons du locuteur cible.

Le procédé comporte ensuite une étape 42 de dénormalisation des informations de fréquence fondamentale transformées.

Cette étape 42 permet de ramener les informations de fréquence fondamentale transformées sur une échelle propre au locuteur cible selon l'équation suivante :

$$F_o[F(x)] = F_o^{moy}(y) . e^{F[g_x(n)]}$$

Dans cette équation $F_o[F(x)]$ correspond à la fréquence fondamentale transformée dénormalisée, $F_o^{moy}(y)$ à la moyenne des valeurs des fréquences fondamentales du locuteur cible et $F[g_x(n)]$ à la transformée de la fréquence fondamentale normalisée du locuteur source.

De manière classique, le procédé de conversion comporte ensuite une étape 44 de synthèse du signal de sortie réalisée, dans l'exemple décrit, par une synthèse de type HNM qui délivre directement le signal vocal converti à partir des informations d'enveloppe spectrale et de fréquence fondamentale transformées délivrées par l'étape 40 et des informations de phase et de fréquence maximale de voisement délivrées par l'étape 36.

Le procédé de conversion mettant en œuvre le procédé d'analyse de l'invention permet ainsi d'obtenir une conversion de voix réalisant conjointement des modifications d'enveloppe spectrales et de fréquence fondamentale, de manière à obtenir un rendu auditif de bonne qualité.

En référence à la figure 2A, on va maintenant décrire l'organigramme général d'un second mode de réalisation du procédé de l'invention.

De même que précédemment, ce procédé comporte la détermination 1 de fonctions de transformation de caractéristiques acoustiques du locuteur source en caractéristiques acoustiques proches de celles du locuteur cible.

Cette détermination 1 débute par la mise en œuvre des étapes 4X et 4Y d'analyse des échantillons vocaux prononcés respectivement par le locuteur source et le locuteur cible.

Ces étapes 4X et 4Y sont fondées sur l'utilisation du modèle HNM ainsi que cela a été décrit précédemment et délivrent chacune un scalaire noté F(n) représentant la fréquence fondamentale et un vecteur noté c(n) comprenant des informations d'enveloppe spectrale sous la forme d'une séquence de coefficients cepstraux.

Dans ce mode de réalisation, ces étapes 4X et 4Y d'analyse sont suivies d'une étape 50 d'alignement des vecteurs de coefficients cepstraux issus de l'analyse des trames du locuteur source et des trames du locuteur cible.

Cette étape 50 est mise en œuvre par un algorithme tel que l'algorithme DTW, de manière similaire à l'étape 18 du premier mode de réalisation.

A l'issue de l'étape 50 d'alignement, le procédé dispose d'un vecteur couple formé de couples de coefficients cepstraux du locuteur source et du locuteur cible, alignés temporellement. Ce vecteur couple est également associé aux informations de fréquence fondamentale.

L'étape 50 d'alignement est suivie d'une étape 54 de séparation, dans le vecteur couple, des trames voisées et des trames non voisées.

En effet, seules les trames voisées présentent une fréquence fondamentale et un tri peut être effectué en considérant si oui ou non des informations de fréquence fondamentale existent pour chaque couple du vecteur couple.

Cette étape de séparation 54 permet ensuite de réaliser la détermination 56 d'une fonction de transformation conjointe des caractéristiques d'enveloppe spectrale et de fréquence fondamentale des trames voisées et la détermination 58 d'une fonction de transformation des seules caractéristiques d'enveloppe spectrale des trames non voisées.

La détermination 56 d'une fonction de transformation des trames voisées débute par des étapes 60X et 60Y de normalisation des informations de fréquence fondamentale respectivement pour les locuteurs source et cible.

Ces étapes 60X et 60Y sont réalisées de manière similaire aux étapes 14X et 14Y du premier mode de réalisation et aboutissent à l'obtention, pour

chaque trame voisée, de la fréquence normalisée pour le locuteur source notée $g_x(n)$ et de celle du locuteur cible notée $g_y(n)$.

Ces étapes 60X et 60Y de normalisation sont suivies chacune d'une étape 62X et 62Y de concaténation des coefficients cepstraux c_x et c_y du locuteur source et du locuteur cible respectivement avec les fréquences normalisées g_x et g_y.

Ces étapes 62X et 62Y de concaténation sont réalisées de manière similaire aux étapes 16X et 16Y et permettent de délivrer un vecteur x_n contenant des informations d'enveloppe spectrale et de fréquence fondamentale pour les trames voisées du locuteur source et un vecteur y_n contenant des informations d'enveloppe spectrale et de fréquence fondamentale normalisées pour les trames voisées du locuteur cible.

De plus, l'alignement entre ces deux vecteurs est conservé tel qu'obtenu à l'issue de l'étape 50, les modifications survenues lors des étapes 60X et 60Y de normalisation et 62X et 62Y de concaténation étant réalisées directement à l'intérieur du vecteur délivré par l'étape 50 d'alignement.

Le procédé comporte ensuite une étape 70 de détermination d'un modèle représentant les caractéristiques communes du locuteur source et du locuteur cible.

A la différence de l'étape 20 décrite en référence à la figure 1A, cette étape 70 est mise en œuvre à partir des informations de fréquence fondamentale et d'enveloppe spectrale des seuls échantillons voisés analysés.

Dans ce mode de réalisation, cette étape 70 est fondée sur un modèle probabiliste selon un mélange de densité gaussienne dit GMM.

L'étape 70 comporte ainsi une sous-étape 72 de modélisation de la densité jointe entre les vecteurs X et Y réalisés de manière similaire à la sous-étape 22 décrite précédemment.

Cette sous-étape 72 est suivie d'une sous-étape 74 d'estimation des paramètres GMM (α, μ et Σ) de la densité p(z).

De même que dans le mode de réalisation décrit précédemment, cette estimation est réalisée à l'aide d'un algorithme de type « EM » permettant l'obtention d'un estimateur de maximum de vraisemblance entre les données des échantillons de paroles et le modèle de mélange de gaussienne.

L'étape 70 délivre donc les paramètres d'un mélange de densités gaussiennes, représentatif des caractéristiques acoustiques communes d'enveloppe spectrale et de fréquence fondamentale des échantillons vocaux voisés du locuteur source et du locuteur cible.

L'étape 70 est suivie d'une étape 80 de détermination d'une fonction conjointe de transformation de la fréquence fondamentale et de l'enveloppe spectrale des échantillons vocaux voisés du locuteur source vers le locuteur cible.

Cette étape 80 est mise en œuvre de manière similaire à l'étape 30 du premier mode de réalisation et en particulier comporte également une sous-étape 82 de détermination de l'espérance conditionnelle des caractéristiques acoustiques du locuteur cible sachant les caractéristiques acoustiques du locuteur source, cette sous-étape étant mise en œuvre selon les mêmes formules que précédemment, appliquées aux seuls échantillons voisés.

L'étape 80 aboutit ainsi à l'obtention d'une fonction de transformation conjointe des caractéristiques d'enveloppe spectrale et de fréquence fondamentale entre le locuteur source et le locuteur cible, applicable aux trames voisées.

Parallèlement à la détermination 56 de cette fonction de transformation des trames voisées, la détermination 58 d'une fonction de transformation des seules caractéristiques d'enveloppe spectrale des trames non voisées est également mise en œuvre.

Dans le mode de réalisation décrit, la détermination 58 comporte une étape 90 de détermination d'une fonction de filtrage définie de manière globale sur les paramètres d'enveloppe spectrale, à partir des couples de trames non voisées.

Cette étape 90 est réalisée de manière classique par la détermination d'un modèle GMM ou encore de tout autre technique adaptée et connue.

A l'issue de la détermination 58, une fonction de transformation des caractéristiques d'enveloppe spectrale des trames non voisées est obtenue.

En référence à la figure 2B, le procédé comporte ensuite la transformation 2 des caractéristiques acoustiques d'un signal vocal à convertir.

De même que dans le mode de réalisation précédent, cette transformation 2 débute par une étape d'analyse 36 du signal vocal à convertir réalisée selon un modèle HNM et une étape 38 de formatage.

Ainsi que cela a été dit précédemment, ces étapes 36 et 38 permettent de délivrer, sous la forme d'un unique vecteur, les informations d'enveloppe spectrale et de fréquence fondamentale normalisée. De plus, l'étape 36 délivre des informations de phase et de fréquence maximale de voisement.

Dans le mode de réalisation décrit, l'étape 38 est suivie d'une étape 100 de séparation, dans le signal à convertir analysé, des trames voisées et des trames non voisées.

Cette séparation est réalisée à l'aide d'un critère fondé sur la présence d'une information de fréquence fondamentale non nulle.

L'étape 100 est suivie d'une étape 102 de transformation des caractéristiques acoustiques du signal vocal à convertir par l'application des fonctions de transformation déterminées lors des étapes 80 et 90.

Plus particulièrement, cette étape 102 comporte une sous-étape 104 d'application de la fonction de transformation conjointe des informations d'enveloppe spectrale et de fréquence fondamentale, déterminée à l'étape 80, aux seules trames voisées telles que séparées à l'issue de l'étape 100.

Parallèlement, l'étape 102 comporte une sous-étape 106 d'application de la fonction de transformation des seules informations d'enveloppe spectrale, déterminée à l'étape 90, aux seules trames non voisées telles que séparées lors de l'étape 100.

La sous-étape 104 délivre ainsi pour chaque trame d'échantillons voisés du signal à convertir du locuteur source, des informations d'enveloppe spectrale et de fréquence fondamentale transformées simultanément et dont les caractéristiques sont similaires à celles des échantillons voisés du locuteur cible.

La sous-étape 106 délivre quant à elle pour chaque trame d'échantillons non voisés du signal à convertir du locuteur source, des informations d'enveloppe spectrale transformées dont les caractéristiques sont similaires à celles des échantillons non voisés du locuteur cible.

Dans le mode de réalisation décrit, le procédé comprend en outre une étape 108 de dénormalisation des informations de fréquence fondamentale transformées, mise en œuvre sur les informations délivrées par la sous-étape

104 de transformation, d'une manière similaire à l'étape 42 décrite en référence à la figure 1B.

Le procédé de conversion comporte ensuite une étape 110 de synthèse du signal de sortie réalisée, dans l'exemple décrit, par une synthèse de type HNM qui délivre le signal vocal converti à partir des informations d'enveloppe spectrale et de fréquence fondamentale transformées ainsi que des informations de phase et de fréquence maximale de voisement pour les trames voisées et à partir des informations d'enveloppe spectrale transformées pour les trames non voisées.

Le procédé de l'invention permet donc, dans ce mode de réalisation, d'effectuer un traitement distinct sur les trames voisées et les trames non voisées, les trames voisées subissant une transformation simultanée des caractéristiques d'enveloppe spectrale et de fréquence fondamentale et les trames non voisées subissant une transformation de leurs seules caractéristiques d'enveloppe spectrale.

Un tel mode de réalisation permet une transformation plus précise que le mode de réalisation précédent tout en conservant une complexité limitée.

L'efficacité d'un procédé de conversion peut être évaluée à partir d'échantillons vocaux identiques prononcés par le locuteur source et le locuteur cible.

Ainsi, le signal vocal prononcé par le locuteur source est converti à l'aide du procédé de l'invention et la ressemblance du signal converti avec le signal prononcé par le locuteur cible est évaluée.

Par exemple, cette ressemblance est calculée sous la forme d'un rapport entre la distance acoustique séparant le signal converti du signal cible et la distance acoustique séparant le signal cible du signal source.

La figure 3 représente un graphique de résultats obtenu dans le cas d'une conversion de voix d'homme en une voix de femme, les fonctions de transformation étant obtenues à partir de bases d'apprentissage contenant chacune 5 minutes de parole échantillonnées à 16 kHz, les vecteurs cepstraux utilisés étant de taille 20 et le modèle GMM étant à 64 composantes.

Ce graphique représente en abscisse les numéros de trames et en ordonnée la fréquence en hertz du signal.

Les résultats représentés sont caractéristiques pour les trames voisées qui s'étendent approximativement des trames 20 à 85.

Sur ce graphique, la courbe Cx représente les caractéristiques de fréquence fondamentale du signal source et la courbe Cy celles du signal cible.

La courbe C_1 représente les caractéristiques de fréquence fondamentale d'un signal obtenu par une conversion linéaire classique.

Il apparaît que ce signal présente la même forme générale que celle du signal source représentée par la courbe Cx.

A l'inverse, la courbe C_2 représente les caractéristiques de fréquence fondamentale d'un signal converti à l'aide du procédé de l'invention tel que décrit en référence aux figures 2A et 2B.

Il transparaît de manière flagrante que la courbe de fréquence fondamentale du signal converti à l'aide du procédé de l'invention présente une forme générale très proche de la courbe de fréquence fondamentale cible Cy.

Sur la figure 4, on a représenté un schéma bloc fonctionnel d'un système de conversion de voix mettant en œuvre le procédé décrit en référence aux figures 2A et 2B.

Ce système utilise en entrée une base de données 120 d'échantillons vocaux prononcés par le locuteur source et une base de données 122 contenant au moins les mêmes échantillons vocaux prononcés par le locuteur cible.

Ces deux bases de données sont utilisées par un module 124 de détermination de fonctions de transformation de caractéristiques acoustiques du locuteur source en caractéristiques acoustiques du locuteur cible.

Ce module 124 est adapté pour la mise en œuvre des étapes 56 et 58 du procédé telles que décrites en référence à la figure 2 et permet donc la détermination d'une fonction de transformation de l'enveloppe spectrale des trames non voisées et d'une fonction de transformation conjointe de l'enveloppe spectrale et de la fréquence fondamentale des trames voisées.

De manière générale, on considère que le module 124 comporte une unité 126 de détermination de la fonction de transformation conjointe de l'enveloppe spectrale et de la fréquence fondamentale des trames voisées et une unité 128 de détermination de la fonction de transformation de l'enveloppe spectrale des trames non voisées.

Le système de conversion de voix reçoit en entrée un signal vocal 130 correspondant à un signal de parole prononcé par le locuteur source et destiné à être converti.

Le signal 130 est introduit dans un module 132 d'analyse du signal, mettant en œuvre, par exemple, une décomposition de type HNM permettant de dissocier des informations d'enveloppe spectrale du signal 130 sous la forme de coefficients cepstraux et des informations de fréquence fondamentale. Le module 132 délivre également des informations de phase et de fréquence maximale de voisement obtenues par l'application du modèle HNM.

Le module 132 met donc en œuvre l'étape 36 du procédé décrit précédemment et avantageusement l'étape 38.

Eventuellement cette analyse peut être faite au préalable et les informations sont stockées pour être utilisées ultérieurement.

Le système comporte ensuite un module 134 de séparation des trames voisées et des trames non voisées dans le signal vocal à convertir analysé.

Les trames voisées, séparées par le module 134, sont transmises à un module 136 de transformation adapté pour appliquer la fonction de transformation conjointe déterminée par l'unité 126.

Ainsi, le module 136 de transformation met en œuvre l'étape 104 décrite en référence à la figure 2B. Avantageusement, le module 136 met également en œuvre l'étape 108 de dénormalisation.

Les trames non voisées, séparées par le module 134, sont transmises à un module 138 de transformation adapté pour appliquer la fonction de transformation déterminée par l'unité 128 de manière à transformer les coefficients cepstraux des trames non voisées.

Ainsi, le module 138 de transformation des trames non voisées met en œuvre l'étape 106 décrite à la figure 2B.

Le système comporte également un module 140 de synthèse recevant en entrée, pour les trames voisées les informations d'enveloppe spectrale et de fréquence fondamentale transformées conjointement et les informations de phase et de fréquence maximale de voisement délivrées par le module 136. Le module 140 reçoit également les coefficients cepstraux des trames non voisées transformés et délivrés par le module 138.

Le module 140 met ainsi en œuvre l'étape 110 du procédé décrit en référence à la figure 2B et délivre un signal 150 correspondant au signal vocal 130 du locuteur source mais dont les caractéristiques d'enveloppe spectrale et de fréquence fondamentale ont été modifiées afin d'être similaires à celles du locuteur cible.

Le système décrit peut être mis en œuvre de diverses manières et notamment à l'aide des programmes informatiques adaptés et reliés à des moyens matériels d'acquisition sonores.

Dans le cadre de l'application du procédé de l'invention, tel que décrit en référence aux figures 1A et 1B, le système comporte dans le module 124, une unique unité de détermination d'une fonction de transformation conjointe de l'enveloppe spectrale et de la fréquence fondamentale.

Dans un tel mode de réalisation, les modules 134 de séparation et 138 d'application de la fonction de transformation des trames non voisées, ne sont pas nécessaires.

Le module 136 permet donc l'application de la seule fonction de transformation conjointe à toutes les trames du signal vocal à convertir et délivre les trames transformées au module 140 de synthèse.

De manière générale, le système est adapté pour la mise en œuvre de toutes les étapes des procédés décrits en référence aux figures 1 et 2.

Dans tous les cas, le système peut également être mis en œuvre sur des bases de données déterminées afin de former des bases de données de signaux convertis prêts à être utilisés.

Par exemple, l'analyse est faite en temps différé et les paramètres de l'analyse HNM sont mémorisés en vue d'une utilisation ultérieure lors des étapes 40 ou 100 par le module 134.

Enfin, en fonction de la complexité des signaux et de la qualité souhaitée, le procédé de l'invention et le système correspondant peuvent être mis en œuvre en temps réel.

Bien entendu d'autres modes de réalisation que ceux décrits peuvent être envisagés.

Notamment, les modèles HNM et GMM peuvent être remplacés par d'autres techniques et modèles connus de l'homme de l'art. Par exemple, l'analyse est réalisée à l'aide de techniques dites LPC (Linear Predictive

Coding), de modèles sinusoïdaux ou MBE (Multi Band Excited), les paramètres spectraux sont des paramètres dits LSF (Line Spectrum Frequencies), ou encore des paramètres liés aux formants ou à un signal glottique. En variante, le modèle GMM est remplacé par une quantification vectorielle (Fuzzy VQ.).

En variante, l'estimateur mis en œuvre lors de l'étape 30 est un critère de maximum a posteriori, dit "MAP" et correspondant à la réalisation du calcul de l'espérance uniquement pour le modèle représentant le mieux le couple de vecteurs source-cible.

Dans une autre variante, la détermination d'une fonction de transformation conjointe est réalisée à l'aide d'une technique dite des moindres carrés au lieu de l'estimation de la densité jointe décrite.

Dans cette variante, la détermination d'une fonction de transformation comprend la modélisation de la densité de probabilité des vecteurs source à l'aide d'un modèle GMM puis la détermination des paramètres du modèle à l'aide d'un algorithme EM. La modélisation prend ainsi en compte des segments de parole du locuteur source dont les correspondants prononcés par le locuteur cible ne sont pas disponibles.

La détermination comprend ensuite la minimisation d'un critère des moindres carrés entre paramètres cible et source pour obtenir la fonction de transformation. Il est à noter que l'estimateur de cette fonction s'exprime toujours de la même manière mais que les paramètres sont estimés différemment et que des données supplémentaires sont prises en compte.

REVENDICATIONS

1. Procédé de conversion d'un signal vocal (130) prononcé par un locuteur source en un signal vocal converti (150) dont les caractéristiques acoustiques ressemblent à celles d'un locuteur cible, comprenant :

- la détermination (1) d'au moins une fonction de transformation de caractéristiques acoustiques du locuteur source en caractéristiques acoustiques proches de celles du locuteur cible, à partir d'échantillons vocaux des locuteurs source et cible ; et

- la transformation (2) de caractéristiques acoustiques du signal vocal à convertir (130) du locuteur source, par l'application de ladite au moins une fonction de transformation,

caractérisé en ce que ladite détermination (1) comprend la détermination (1; 56) d'une fonction de transformation conjointe de caractéristiques relatives à l'enveloppe spectrale et de caractéristiques relatives à la fréquence fondamentale du locuteur source et en ce que ladite transformation (2) comprend l'application de ladite fonction de transformation conjointe.

2. Procédé selon la revendication 1, caractérisé en ce que ladite détermination (1 ; 56) d'une fonction de transformation conjointe comprend :

- une étape (4X, 4Y) d'analyse des échantillons vocaux des locuteurs source et cible regroupés en trames pour obtenir, pour chaque trame d'échantillons d'un locuteur, des informations relatives à l'enveloppe spectrale et à la fréquence fondamentale ;

- une étape (16X, 16Y ; 62X, 62Y) de concaténation des informations relatives à l'enveloppe spectrale et à la fréquence fondamentale pour chacun des locuteurs source et cible ;

- une étape (20 ; 70) de détermination d'un modèle représentant des caractéristiques acoustiques communes des échantillons vocaux du locuteur source et du locuteur cible ; et

- une étape (30 ; 80) de détermination, à partir de ce modèle et des échantillons vocaux, de ladite fonction de transformation conjointe.

3. Procédé selon la revendication 2, caractérisé en ce que lesdites étapes d'analyse (4X,4Y) des échantillons vocaux des locuteurs source et cible sont adaptées pour délivrer lesdites informations relatives à l'enveloppe spectrale sous la forme de coefficients cepstraux.

4. Procédé selon la revendication 2 ou 3, caractérisé en ce que lesdites étapes (4X, 4Y) d'analyse comprennent chacune la modélisation des échantillons vocaux selon une somme d'un signal harmonique et d'un signal de bruit qui comprend :

- une sous-étape (8X, 8Y) d'estimation de la fréquence fondamentale des échantillons vocaux ;
- une sous-étape (10X, 10Y) d'analyse synchronisée de chaque trame d'échantillons sur sa fréquence fondamentale ; et
- une sous-étape (12X, 12Y) d'estimation de paramètres d'enveloppe spectrale de chaque trame d'échantillons.

5. Procédé selon l'une quelconque des revendications 2 à 4, caractérisé en ce que ladite étape (20 ; 70) de détermination d'un modèle correspond à la détermination d'un modèle de mélange de densités de probabilités gaussiennes.

6. Procédé selon la revendication 5, caractérisé en ce que ladite étape de détermination (20 ; 70) d'un modèle comprend :

- une sous-étape (22, 72) de détermination d'un modèle correspondant à un mélange de densités de probabilités gaussiennes, et
- une sous-étape (24, 74) d'estimation des paramètres du mélange de densités de probabilités gaussiennes à partir de l'estimation du maximum de vraisemblance entre les caractéristiques acoustiques des échantillons des locuteurs source et cible et le modèle.

7. Procédé selon l'une quelconque des revendications 2 à 6, caractérisé en ce que ladite détermination (1 : 56) d'au moins une fonction de transformation, comporte en outre une étape (14X, 14Y ; 60X, 60Y) de normalisation de la fréquence fondamentale des trames d'échantillons des locuteurs source et cible respectivement par rapport aux moyennes des fréquences fondamentales des échantillons analysés des locuteurs source et cible.

8. Procédé selon l'une quelconque des revendications 2 à 7, caractérisé en ce qu'il comporte une étape (18 ; 50) d'alignement temporel des caractéristiques acoustiques du locuteur source avec les caractéristiques acoustiques du locuteur cible, cette étape (18 ; 50) étant réalisée avant ladite étape (20 ; 70) de détermination d'un modèle conjoint.

9. Procédé selon l'une quelconque des revendications 1 à 8, caractérisé en ce qu'il comporte une étape (54) de séparation dans les échantillons vocaux du locuteur source et du locuteur cible, des trames à caractère voisé et des trames à caractère non voisé, ladite détermination (56) d'une fonction de transformation conjointe des caractéristiques relatives à l'enveloppe spectrale et à la fréquence fondamentale étant réalisée uniquement à partir desdites trames voisées et le procédé comportant une détermination (58) d'une fonction de transformation des seules caractéristiques d'enveloppe spectrale uniquement à partir desdites trames non voisées.

10. Procédé selon l'une quelconque des revendications 1 à 8, caractérisé en ce que ladite détermination (1) d'au moins une fonction de transformation comprend uniquement ladite étape (1) de détermination d'une fonction de transformation conjointe.

11. Procédé selon l'une quelconque des revendications 1 à 10, caractérisé en ce que ladite détermination (1 ; 56) d'une fonction de transformation conjointe est réalisée à partir d'un estimateur de la réalisation des caractéristiques acoustiques du locuteur cible sachant les caractéristiques acoustiques du locuteur source.

12. Procédé selon la revendication 11, caractérisé en ce que ledit estimateur est formé de l'espérance conditionnelle de la réalisation des caractéristiques acoustiques du locuteur cible sachant la réalisation des caractéristiques acoustiques du locuteur source.

13. Procédé selon l'une quelconque des revendications 1 à 12, caractérisé en ce que ladite transformation (2) de caractéristiques acoustiques du signal vocal à convertir (130), comporte :

- une étape (36) d'analyse de ce signal vocal (130), regroupé en trames pour obtenir, pour chaque trame d'échantillons, des informations relatives à l'enveloppe spectrale et à la fréquence fondamentale ;

- une étape (38) de formatage des informations acoustiques relatives à l'enveloppe spectrale et à la fréquence fondamentale du signal vocal à convertir ; et

- une étape (40 ; 102) de transformation des informations acoustiques formatées du signal vocal à convertir (130) à l'aide de ladite fonction de transformation conjointe.

14. Procédé selon les revendications 9 et 13 prises ensemble, caractérisé en ce qu'il comporte une étape (100) de séparation, dans ledit signal vocal à convertir (130), des trames voisées et des trames non voisées, ladite étape de transformation comprenant :

- une sous-étape (104) d'application de ladite fonction de transformation conjointe aux seules trames voisées dudit signal à convertir (130) ; et

- une sous-étape (106) d'application de ladite fonction de transformation des seules caractéristiques d'enveloppe spectrale auxdites trames non voisées dudit signal à convertir (130).

15. Procédé selon les revendications 10 et 13 prises ensemble, caractérisé en ce que ladite étape de transformation comprend l'application de ladite fonction de transformation conjointe aux caractéristiques acoustiques de toutes les trames dudit signal vocal à convertir (130).

16. Procédé selon l'une quelconque des revendications 1 à 15, caractérisé en ce qu'il comporte en outre une étape (44 ; 110) de synthèse permettant de former un signal vocal converti (150) à partir des dites informations acoustiques transformées.

17. Système de conversion d'un signal vocal (130) prononcé par un locuteur source en un signal vocal converti (150) dont les caractéristiques acoustiques ressemblent à celles d'un locuteur cible, comprenant :

- des moyens (124) de détermination d'au moins une fonction de transformation des caractéristiques acoustiques du locuteur source en caractéristiques acoustiques proches du locuteur cible, à partir d'échantillons vocaux prononcés par les locuteurs source et cible : et

- des moyens (136, 138) de transformation des caractéristiques acoustiques du signal vocal à convertir (130) du locuteur source par l'application de ladite au moins une fonction de transformation,

caractérisé en ce que lesdits moyens (124) de détermination d'au moins une fonction de transformation, comprennent une unité (126) de détermination d'une fonction de transformation conjointe de caractéristiques relatives à l'enveloppe spectrale et de caractéristiques relatives à la fréquence fondamentale du locuteur source et en ce que lesdits moyens de transformation

comportent des moyens (136) d'application de ladite fonction de transformation conjointe.

18. Système selon la revendication 17, caractérisé en ce qu'il comporte en outre :

- des moyens (132) d'analyse du signal vocal à convertir (130), adaptés pour délivrer en sortie des informations relatives à l'enveloppe spectrale et à la fréquence fondamentale du signal vocal à convertir (130) ; et

- des moyens (140) de synthèse permettant de former un signal vocal converti à partir au moins desdites informations d'enveloppe spectrale et de fréquence fondamentale transformées simultanément.

19. Système selon l'une quelconque des revendications 17 et 18, caractérisé en ce que lesdits moyens (124) de détermination d'au moins une fonction de transformation de caractéristiques acoustiques comportent en outre une unité (128) de détermination d'une fonction de transformation de l'enveloppe spectrale des trames non voisées, ladite unité (126) de détermination de la fonction de transformation conjointe étant adaptée pour la détermination de la fonction de transformation conjointe uniquement pour les trames voisées.

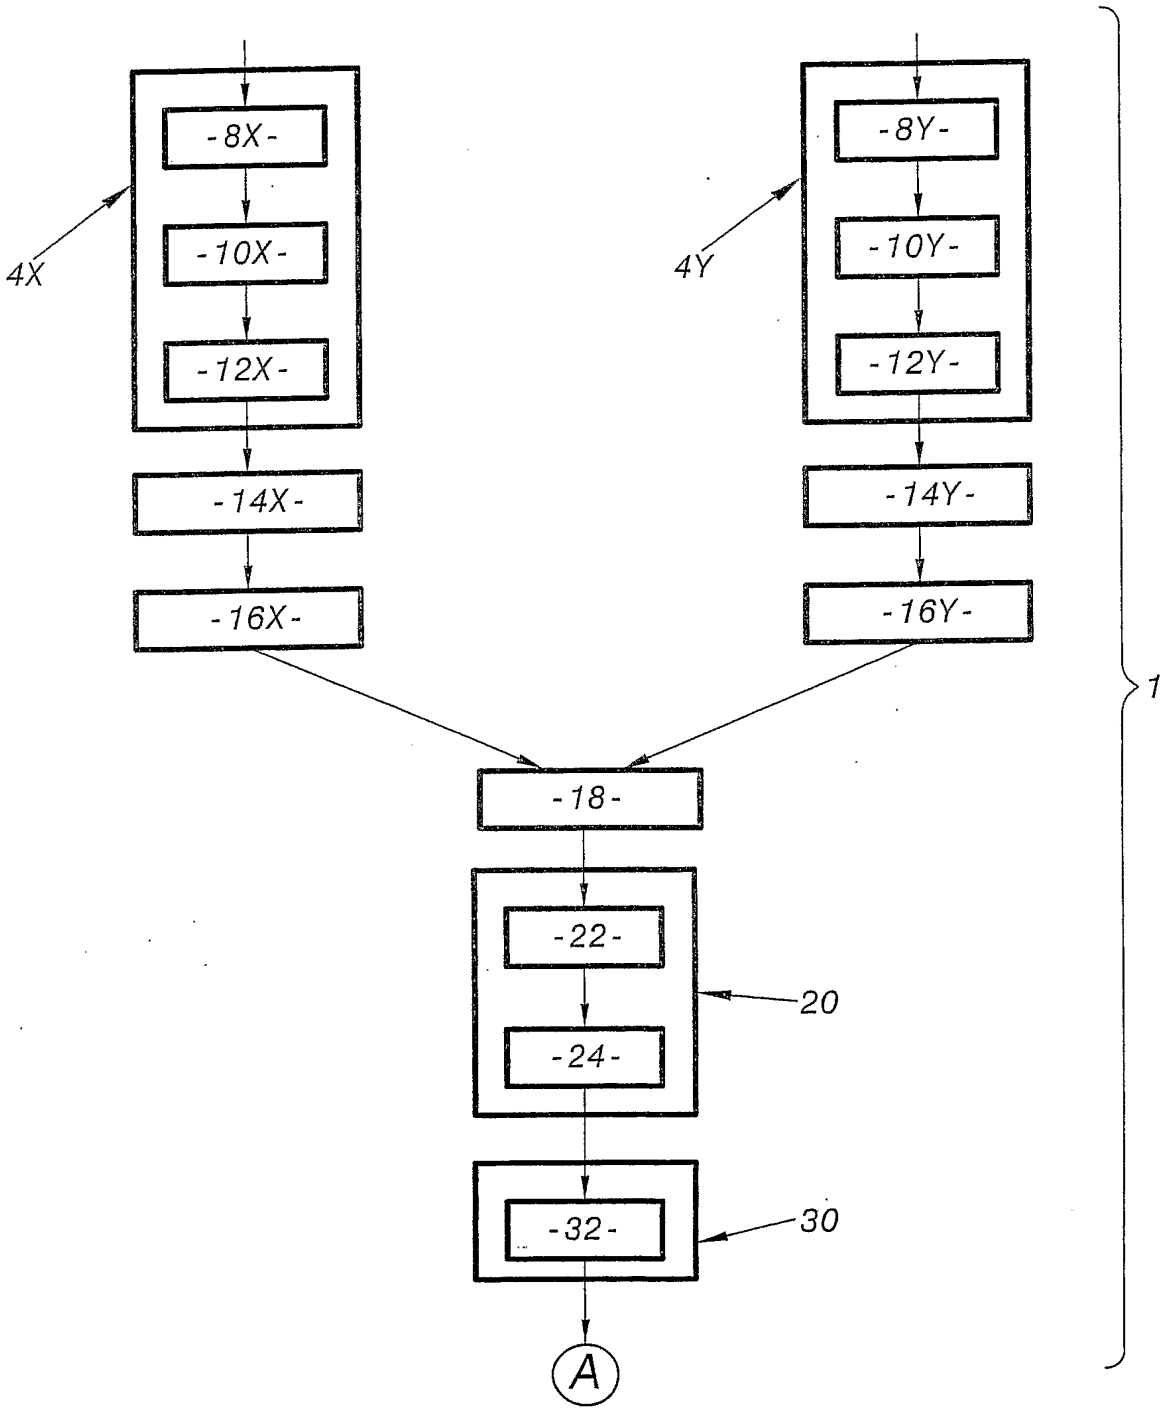

FIG.1A

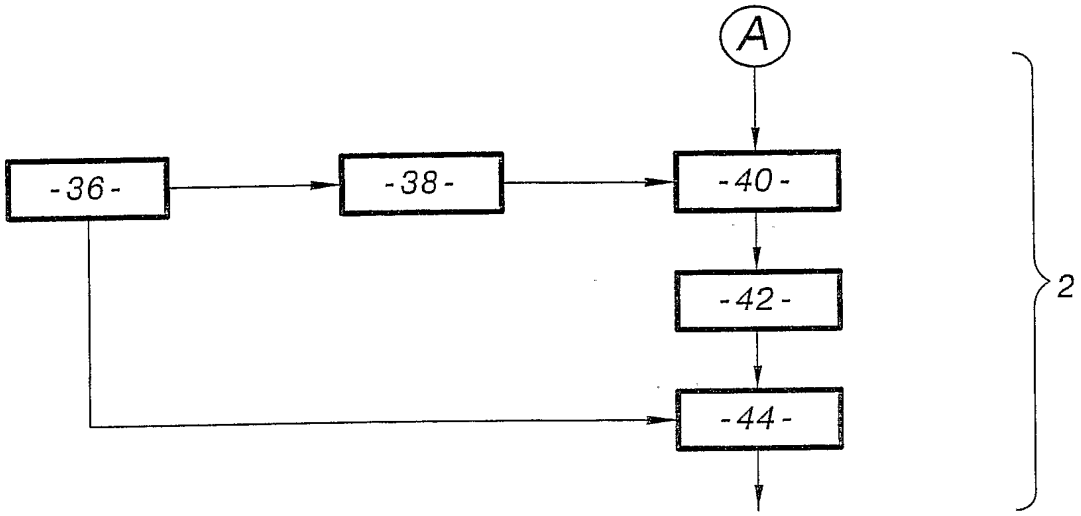

FIG.1B

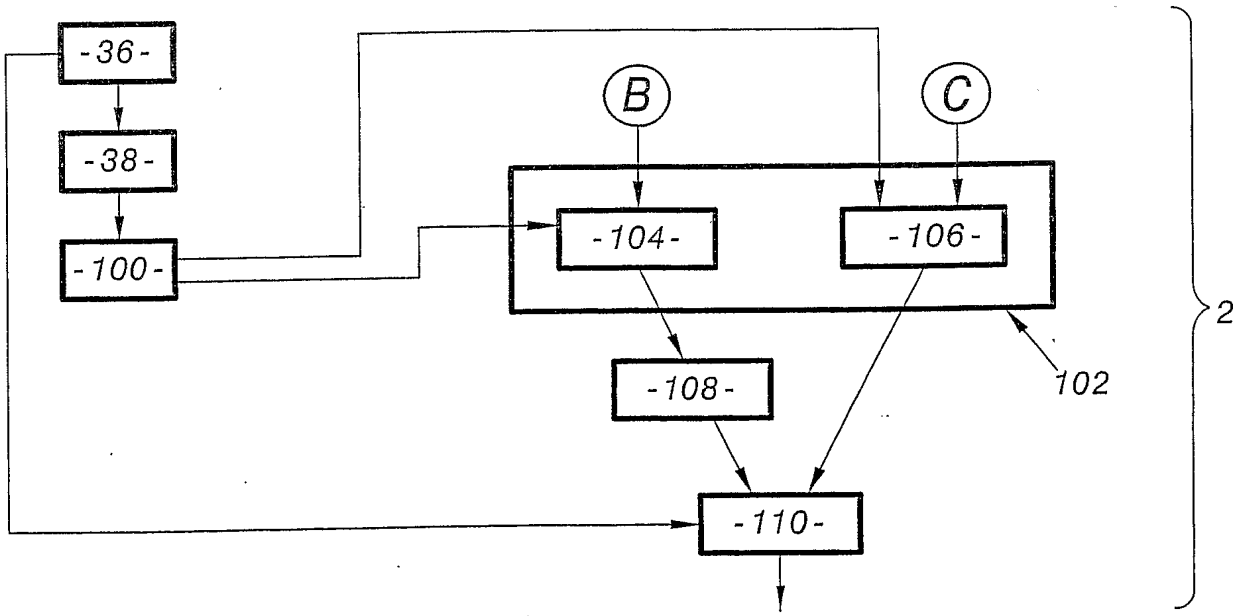

FIG.2B

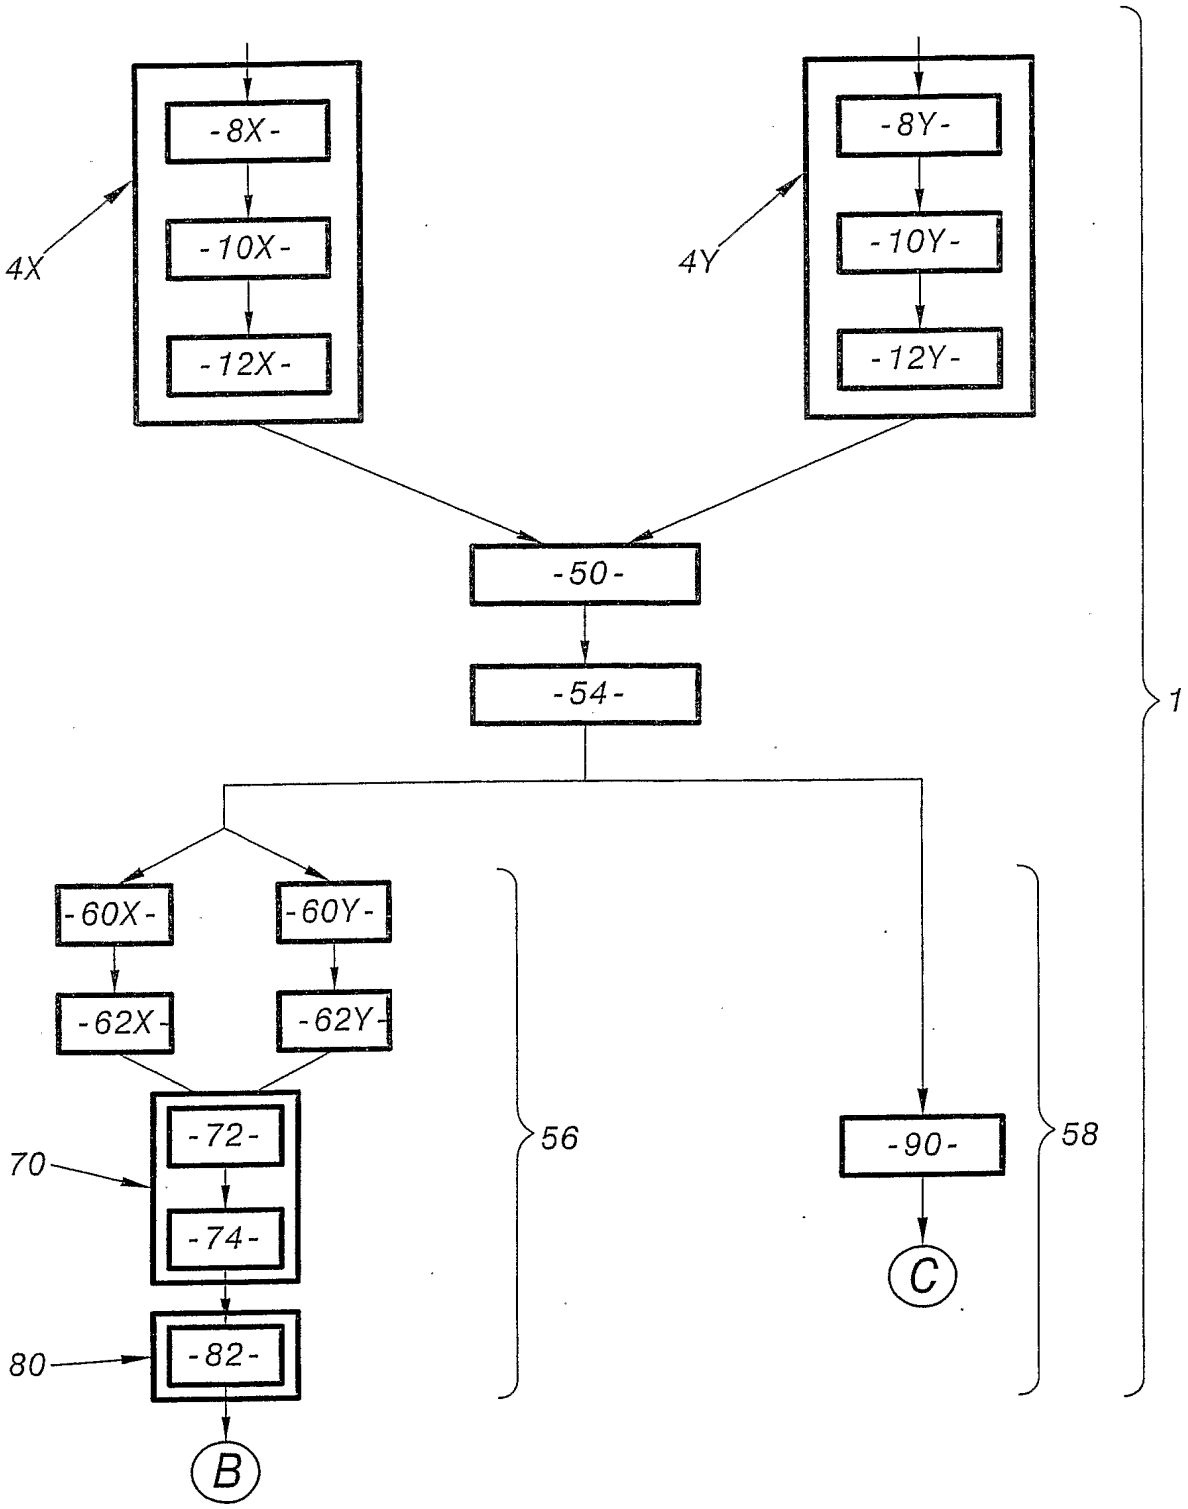
-8X-
-10X-
-12X-
4X
-8Y-
-10Y-
-12Y-
4Y
-50-
-54-
1
-60X-
-60Y-
-62X-
-62Y-
-72-
-74-
-82-
70
80
56
-90-
58
C
B

FIG.2A

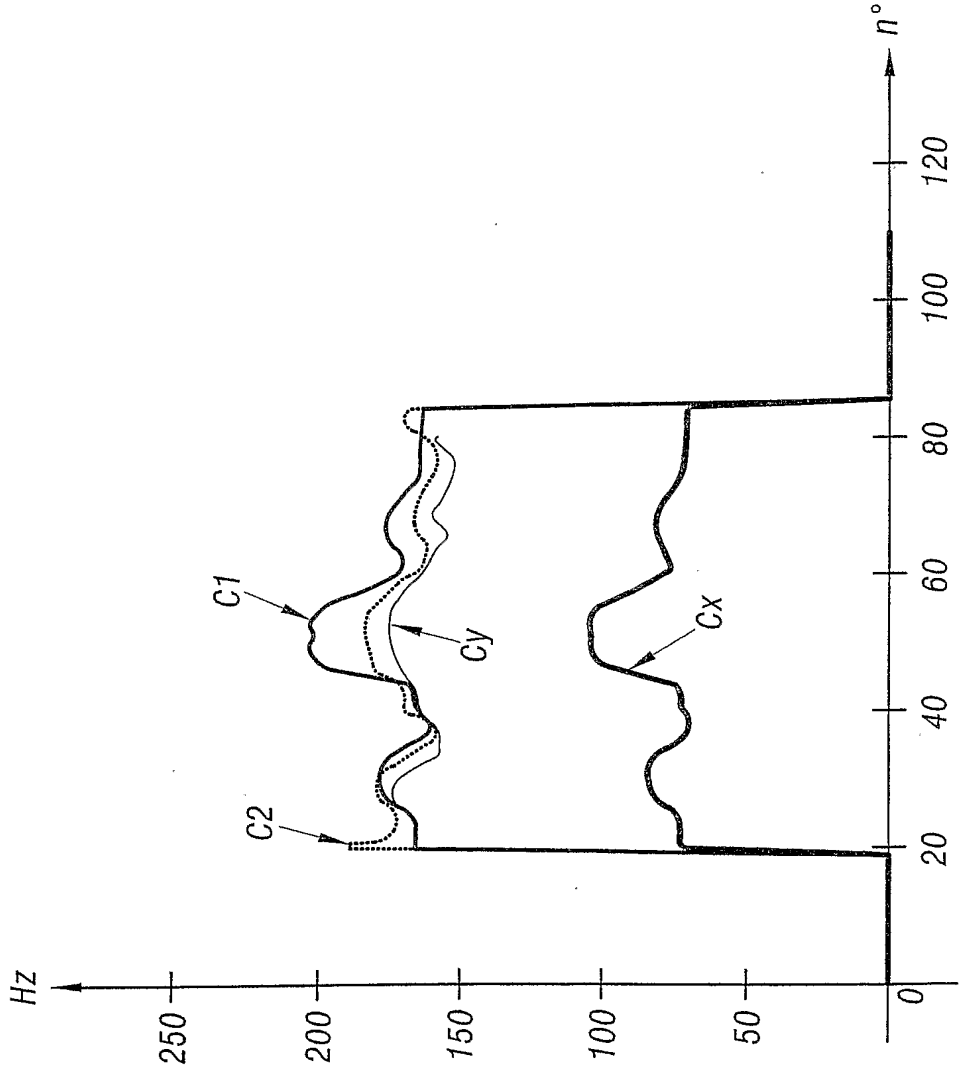

FIG.3

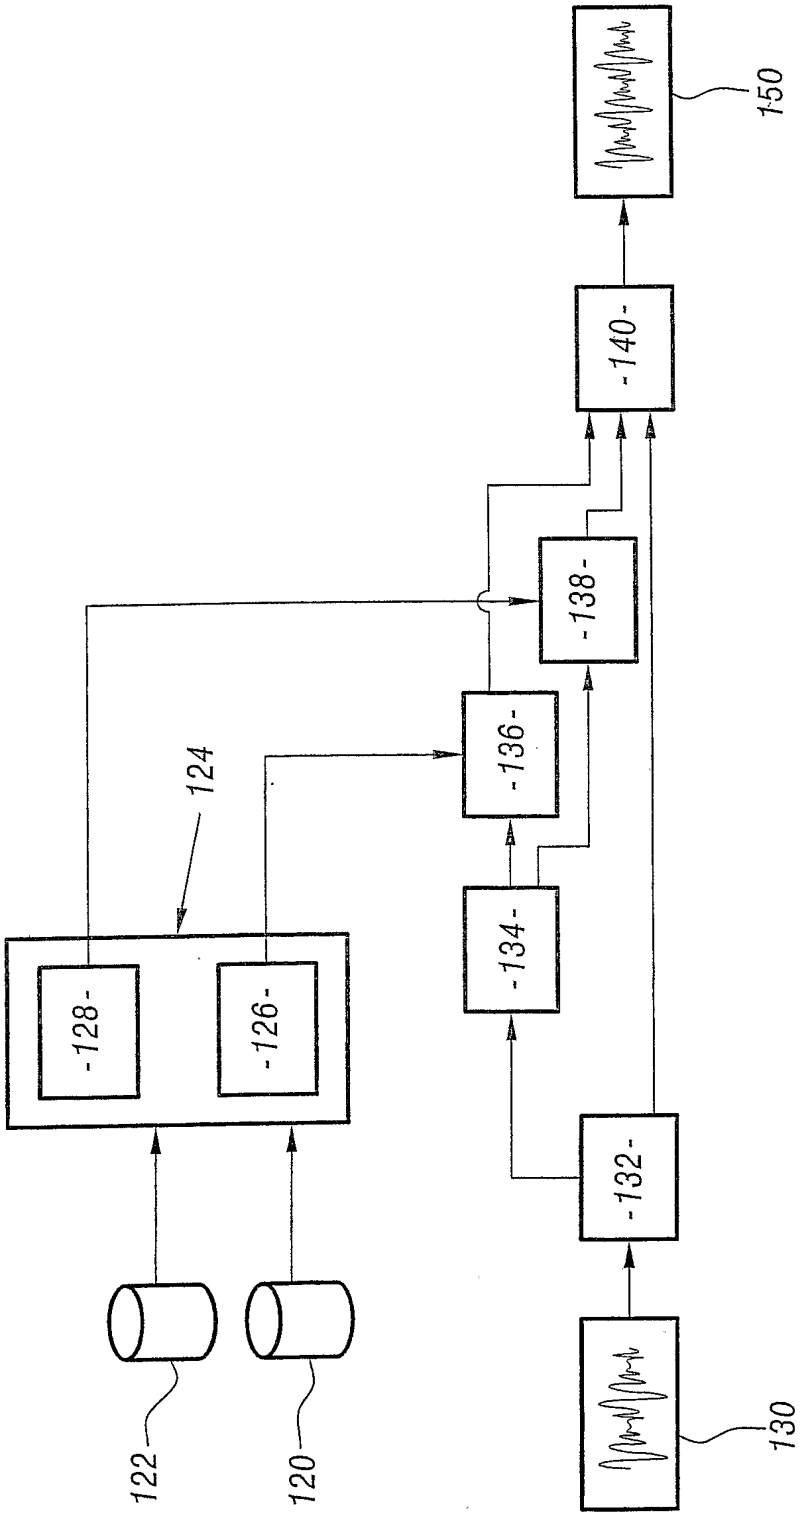

FIG.4

INTERNATIONAL SEARCH REPORT

International Application No
PCT/FR2005/000564

A. CLASSIFICATION OF SUBJECT MATTER
IPC 7 G10L21/00 G10L13/02

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)
IPC 7 G10L

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practical, search terms used)

EPO-Internal, WPI Data, PAJ, IBM-TDB, INSPEC, COMPENDEX

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category °	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
X	CHING-HSIANG HO: "Speaker Modelling for Voice Conversion" PHD THESIS, CHAPTER IV, 'Online! July 2001 (2001-07), pages 1-29, XP002294430 Retrieved from the Internet: URL:http://www.brunel.ac.uk/depts/ee/Research_Programme/COM/charlesPHDthesis/Chapter4.pdf> 'retrieved on 2004-08-30!	1,2, 16-18
Y	page 2, paragraph 4.1; figure 4.1 page 4, line 4 - line 35 page 8, line 21 - page 9, line 15 page 9, line 29 - page 10, line 6 page 9, équation 4.3	3-15,19

-/--

[X] Further documents are listed in the continuation of box C.

[ ] Patent family members are listed in annex.

° Special categories of cited documents :

"A" document defining the general state of the art which is not considered to be of particular relevance

"E" earlier document but published on or after the international filing date

"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

"O" document referring to an oral disclosure, use, exhibition or other means

"P" document published prior to the international filing date but later than the priority date claimed

"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art.

"&" document member of the same patent family

Date of the actual completion of the international search	Date of mailing of the international search report
10 June 2005	05/07/2005

Name and mailing address of the ISA	Authorized officer
European Patent Office, P.B. 5818 Patentlaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 651 epo nl, Fax: (+31-70) 340-3016	Dobler, E

1

Form PCT/ISA/210 (second sheet) (January 2004)

INTERNATIONAL SEARCH REPORT

International Application No
PCT/FR2005/000564

C.(Continuation) DOCUMENTS CONSIDERED TO BE RELEVANT

Category °	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y	STYLIANOU Y ET AL: "A system for voice conversion based on probabilistic classification and a harmonic plus noise model" ACOUSTICS, SPEECH AND SIGNAL PROCESSING, 1998. PROCEEDINGS OF THE 1998 IEEE INTERNATIONAL CONFERENCE ON SEATTLE, WA, USA 12-15 MAY 1998, NEW YORK, NY, USA,IEEE, US, 12 May 1998 (1998-05-12), pages 281-284, XP010279158 ISBN: 0-7803-4428-6 abstract page 281, right-hand column, line 36 - page 283, left-hand column, line 27	3-15,19
A	TAOUFIK EN-NAJJARY ET AL: "A new method for pitch prediction from spectral envelope and its application in voice conversion" ACTES DE CONFERENCES EUROSPEECH 2003, September 2003 (2003-09), page 1753, XP007006844 cited in the application page 1753, left-hand column, line 41 - right-hand column, line 2 page 1754, paragraph 2.2.3	7
A	KAIN A ET AL: "Stochastic modeling of spectral adjustment for high quality pitch modification" ACTES DE CONFERENCES ICASSP 2000, vol. 2, 5 June 2000 (2000-06-05), pages 949-952, XP010504881 page 949, left-hand column, line 1 - page 951, left-hand column, line 12	1-19
A	YINING CHEN1 ET AL: "Voice Conversion with Smoothed GMM and MAP Adaptation" ACTES DE CONFERENCES EUROSPEECH 2003, September 2003 (2003-09), pages 2413-2416, XP007006960 page 2414, left-hand column, paragraph 2.2 page 2413, left-hand column, line 25 - line 37	1,16

1

RAPPORT DE RECHERCHE INTERNATIONALE

Demande internationale No
PCT/FR2005/000564

A. CLASSEMENT DE L'OBJET DE LA DEMANDE
CIB 7 G10L21/00 G10L13/02

Selon la classification internationale des brevets (CIB) ou à la fois selon la classification nationale et la CIB

B. DOMAINES SUR LESQUELS LA RECHERCHE A PORTE

Documentation minimale consultée (système de classification suivi des symboles de classement)
CIB 7 G10L

Documentation consultée autre que la documentation minimale dans la mesure où ces documents relèvent des domaines sur lesquels a porté la recherche

Base de données électronique consultée au cours de la recherche internationale (nom de la base de données, et si réalisable, termes de recherche utilisés)
EPO-Internal, WPI Data, PAJ, IBM-TDB, INSPEC, COMPENDEX

C. DOCUMENTS CONSIDERES COMME PERTINENTS

Catégorie °	Identification des documents cités, avec, le cas échéant, l'indication des passages pertinents	no. des revendications visées
X	CHING-HSIANG HO: "Speaker Modelling for Voice Conversion" PHD THESIS, CHAPTER IV, 'Online! juillet 2001 (2001-07), pages 1-29, XP002294430 Extrait de l'Internet: URL:http://www.brunel.ac.uk/depts/ee/Research_Programme/COM/charlesPHDthesis/Chapter 4.pdf> 'extrait le 2004-08-30!	1,2, 16-18
Y	page 2, alinéa 4.1; figure 4.1 page 4, ligne 4 - ligne 35 page 8, ligne 21 - page 9, ligne 15 page 9, ligne 29 - page 10, ligne 6 page 9, équation 4.3	3-15,19

-/--

[X] Voir la suite du cadre C pour la fin de la liste des documents

[ ] Les documents de familles de brevets sont indiqués en annexe

° Catégories spéciales de documents cités:

"A" document définissant l'état général de la technique, non considéré comme particulièrement pertinent
"E" document antérieur, mais publié à la date de dépôt international ou après cette date
"L" document pouvant jeter un doute sur une revendication de priorité ou cité pour déterminer la date de publication d'une autre citation ou pour une raison spéciale (telle qu'indiquée)
"O" document se référant à une divulgation orale, à un usage, à une exposition ou tous autres moyens
"P" document publié avant la date de dépôt international, mais postérieurement à la date de priorité revendiquée
"T" document ultérieur publié après la date de dépôt international ou la date de priorité et n'appartenenant pas à l'état de la technique pertinent, mais cité pour comprendre le principe ou la théorie constituant la base de l'invention
"X" document particulièrement pertinent; l'invention revendiquée ne peut être considérée comme nouvelle ou comme impliquant une activité inventive par rapport au document considéré isolément
"Y" document particulièrement pertinent; l'invention revendiquée ne peut être considérée comme impliquant une activité inventive lorsque le document est associé à un ou plusieurs autres documents de même nature, cette combinaison étant évidente pour une personne du métier
"&" document qui fait partie de la même famille de brevets

Date à laquelle la recherche internationale a été effectivement achevée	Date d'expédition du présent rapport de recherche internationale
10 juin 2005	05/07/2005

Nom et adresse postale de l'administration chargée de la recherche internationale	Fonctionnaire autorisé
Office Européen des Brevets, P.B. 5818 Patentlaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 651 epo nl, Fax: (+31-70) 340-3016	Dobler, E

1

C.(suite) DOCUMENTS CONSIDERES COMME PERTINENTS

Catégorie °	Identification des documents cités, avec, le cas échéant, l'indication des passages pertinents	no. des revendications visées
Y	STYLIANOU Y ET AL: "A system for voice conversion based on probabilistic classification and a harmonic plus noise model" ACOUSTICS, SPEECH AND SIGNAL PROCESSING, 1998. PROCEEDINGS OF THE 1998 IEEE INTERNATIONAL CONFERENCE ON SEATTLE, WA, USA 12-15 MAY 1998, NEW YORK, NY, USA,IEEE, US, 12 mai 1998 (1998-05-12), pages 281-284, XP010279158 ISBN: 0-7803-4428-6 abrégé page 281, colonne de droite, ligne 36 - page 283, colonne de gauche, ligne 27	3-15,19
A	TAOUFIK EN-NAJJARY ET AL: "A new method for pitch prediction from spectral envelope and its application in voice conversion" ACTES DE CONFERENCES EUROSPEECH 2003, septembre 2003 (2003-09), page 1753, XP007006844 cité dans la demande page 1753, colonne de gauche, ligne 41 - colonne de droite, ligne 2 page 1754, alinéa 2.2.3	7
A	KAIN A ET AL: "Stochastic modeling of spectral adjustment for high quality pitch modification" ACTES DE CONFERENCES ICASSP 2000, vol. 2, 5 juin 2000 (2000-06-05), pages 949-952, XP010504881 page 949, colonne de gauche, ligne 1 - page 951, colonne de gauche, ligne 12	1-19
A	YINING CHEN1 ET AL: "Voice Conversion with Smoothed GMM and MAP Adaptation" ACTES DE CONFERENCES EUROSPEECH 2003, septembre 2003 (2003-09), pages 2413-2416, XP007006960 page 2414, colonne de gauche, alinéa 2.2 page 2413, colonne de gauche, ligne 25 - ligne 37	1,16

1